

DOI: 10.19650/j.cnki.cjsi.J2311549

基于多尺度特征的管道环焊缝定位方法研究^{*}

赵东升^{1,2}, 杨理践¹, 耿浩¹, 郑福印¹, 田野³

(1. 沈阳工业大学信息科学与工程学院 沈阳 110870; 2. 沈阳工程学院自动化学院 沈阳 110136;
3. 管网集团(新疆)联合管道有限责任公司 乌鲁木齐 830000)

摘要:环焊缝是管道检测数据分析的重要参照物,可用于修正里程轮的累积误差,因此,标定环焊缝是管道漏磁内检测数据分析的必要环节。本文结合漏磁数据的特征和环焊缝在管壁上的空间分布特征,提出一种具有多尺度感受野的轻量化卷积神经网络模型。模型利用具有单传感器感受野的轴向一维卷积和具有周向全局感受野的周向环形卷积,使得环焊缝特征得到了有效提取。借鉴标签平滑的思想,对样本标签进行了增广设计。此外,对损失函数、激活函数也进行了优化设计,最终实现对环焊缝的智能定位。最后,从多种管径的在役管道检测数据中收集了5 676个样本,对模型进行了训练和评估。实验结果显示,模型具有较好收敛稳定性,在测试集上的精度达到了93.90%,召回率达到了94.79%。此外,利用未参与模型训练的 $\Phi 610$ 管道漏磁内检测数据,对模型进行了应用测试,模型同样表现出了较好的鲁棒性,其 $F1$ 值达到了0.93,说明模型具有较好的泛化能力,具备一定的工程应用价值。

关键词:管道环焊缝;多尺度;卷积神经网络;智能定位

中图分类号: TH878 **文献标识码:** A **国家标准学科分类代码:** 510.40

Research on the localization method of pipeline girth weld based on multi-scale feature

Zhao Dongsheng^{1,2}, Yang Lijian¹, Geng Hao¹, Zheng Fuyin¹, Tian Ye³

(1. School of Information Science and Engineering, Shenyang University of Technology, Shenyang 110870, China;
2. College of Automation, Shenyang Institute of Engineering, Shenyang 110136, China; 3. PipeChina
(Xinjiang) United Pipeline Co., Ltd., Urumchi 830000, China)

Abstract: Girth weld is an important reference for the pipeline test data analysis which can be used to correct cumulative errors of odometer wheel. Thus, girth weld localization is the necessary part in test data analysis task. In this article, a lightweight convolution neural network with multi-scale receptive field is proposed, which is based on the magnetic flux leakage (MFL) data feature and the girth weld spatial distribution characteristics on the wall of pipeline. The features of girth weld can be extracted efficiently due to the axial 1D convolution with single sensor receptive field and circular ring convolution with circular global receptive field. Inspired by the label smoothing, the sample label is augmented. Moreover, some optimization design for loss function and activation function are also achieved. And a girth weld intelligent localization model is established. Finally, the model is trained and evaluated by the dataset including 5 676 samples that collected from various pipelines on-line MFL inspection data. The experiment results show that model has good convergency stability, and the test precision and recall rate reach 93.90% and 94.79%, respectively. Furthermore, the model is tested by MFL data of $\Phi 610$ pipeline which never participate in model training. The $F1$ score reaches 0.93 which shows that the model has a good robustness and generalization ability, and has certain application engineering value.

Keywords: pipeline girth weld; multi-scale; convolution network; intelligent localization

0 引言

管道漏磁内检测仍然是管道维护的主要手段之一,是保证管道安全运行的有效方式^[1]。管道内检测的后续任务是对检测数据进行判读和分析,从而找出缺陷并指出所在的位置。管道内检测器利用里程轮计量检测数据所在的位置,但由于打滑、振动等因素,里程数据存在累积误差,随着里程数的增加,累积误差将不可忽略。管道一旦建成后,管节的数量和各管节的长度是已知的,于是,管道各环焊缝在整个管线中的里程值也是已知的,因此,数据分析人员往往利用环焊缝作为参照物,对里程数据进行修正,从而得到较为精确的缺陷位置信息。所以,标定环焊缝成为管道数据分析的必要环节。

近年来,人工智能技术得到了长足发展,在计算机视觉、自然语言处理等领域均取得了诸多令人瞩目的成就,并得到了广泛地应用。其中,卷积神经网络在图像识别、物体检测、图像语义分割等任务中表现出了极强的特征表示能力和优异的推理性能,且仍然发挥着重要的作用。在纷繁复杂的应用场景中,为了更加有效地进行特征提取,各种多尺度方法或思想被广泛应用于卷积神经网络模型中。在 Inception 网络^[2]中,大量使用的 Inception 块即包含多种尺寸的卷积核,从而使网络的特征表示能力得到保证;文献[3]在滚动轴承故障诊断模型中,利用自校正卷积学习信号的多尺度特征,提高模型获取有用故障特征的能力;文献[4]提出了一种轻量型自适应多尺度卷积神经网络,研制了轨道入侵异物自主检测系统;文献[5]在铸件缺陷检测任务中,利用特征金字塔结构改进特征提取网络模块,实现多尺度的特征融合;文献[6]为了提升无人艇对典型水面小目标感知能力,在改进型单阶段多框目标检测(single shot multibox detector, SSD)算法中使用了多尺度卷积融合结构;文献[7]为了提高 CenterNet 无锚框目标检测网络对多尺度目标的表达能力,使用了多尺度特征提取网络;文献[8]在 YOLOX 的特征融合网络中新增浅层检测尺度进行特征融合,从而提升小目标的检测能力;文献[9]为了抓取更多的脸部细节和篡改内容,引入了带孔多尺度卷积模块和深度可分离卷积;文献[10]利用 Inception 模块提取视网膜血管的多种尺度特征。以上各文献的成果中,利用多尺度的方法或思想均使模型性能在不同程度上得到了提升。

目前,在管道检测领域,针对管道焊缝的研究工作,主要集中在焊缝裂纹或缺陷的识别、检测或量化任务上。文献[11]利用磁粉检测方法对各种焊缝表面裂纹检测技术的可靠性和灵敏度进行评估;文献[12]利用金属磁记忆理论研究长输油气管道焊缝内部裂纹的量化方法;文献[13]将一维管道漏磁信号转换成时频图,再利用辅

助分类器生成对抗网络(auxiliary classifier generative adversarial network, AC GAN)模型实现管道焊缝缺陷的识别;文献[14]提出一个基于主动学习的轻量化神经网络,实现对复杂管道焊缝缺陷的检测。文献[15]采用生成对抗网络数据增强、残差神经网络等技术对环焊缝的缺陷进行识别。此外,少量学者研究管道焊缝本身的识别或分类方法。文献[16]使用经过预训练和筛选后的卷积核构建卷积神经网络,通过该网络自动提取焊缝图像中的特征,实现了环焊缝与螺旋焊缝的自动分类;文献[17]提出了一个改进的级联区域卷积神经网络(cascade region-based convolutional neural network, Cascade R-CNN)模型,对多种管道检测对象进行识别。以上模型均非针对环焊缝定位而建立的模型,也未能突出环焊缝的空间分布特征,因此,在模型的规模和推理速度上无法进行针对性的优化。

本文考虑到环焊缝在管道漏磁内检测数据分析中的作用,提出一种用于环焊缝智能定位的多尺度卷积、轻量化神经网络模型。模型针对漏磁数据的特征和环焊缝在管壁中的空间分布特征,使用了轴向一维卷积和周向环形卷积,使得模型具有了多尺度感受野,进而能够更有效地提取环焊缝的特征,同时提高模型收敛的稳定性。借鉴标签平滑的思想,对样本标签进行了增广设计,保证了模型的鲁棒性。此外,在激活函数和损失函数的选择上,也进行了实验和优化。最终,建立一个具有一定工程应用价值的管道漏磁内检测数据环焊缝智能定位模型。

1 管道漏磁内检测

1.1 漏磁内检测数据

管道漏磁内检测器的漏磁传感器沿管道周向等间隔并行分布,从而实现周向各钟点方向管壁的并行漏磁检测。检测器被投入管道后,将随着管道内的介质流动而运动,并以一定的采样率对漏磁传感器进行采样。当管壁材料的磁导率发生变化时,便会形成漏磁场,漏磁传感器返回的数据会有幅值上的变化。漏磁数据在列方向呈环形闭合、行方向近似无线延伸。

然而,由于检测器振动造成的传感器脱离、外界电磁环境的干扰等因素,不同探头传感器返回的数据往往有一定差异,例如,各传感器漏磁信号可能呈现不同的基值。

1.2 环焊缝的空间分布特征

管道相邻管节之间以焊接的方式进行连接,于是,会形成一条沿管道周向分布且闭合的圆环,行业上通常称之为环焊缝。焊缝与管壁的材质不同,磁导率也存在明显差异,因此,在焊缝附近会形成较强的漏磁场,相应地,

漏磁信号会呈现较为明显的幅值突变。图1展示了一条环焊缝各漏磁传感器信号波形。




图1 环焊缝漏磁信号

Fig. 1 Magnetic flux leakage signal of girth weld

从图1中可以看到,同一环焊缝在周向各钟点漏磁传感器上产生的漏磁信号具有相近的轴向坐标,或者说,在漏磁数据中,同一环焊缝的漏磁信号幅值突变位置在

列方向上较为集中,这是环焊缝区别于其他管道部件的重要特征,本文在模型设计上给予了充分地考虑。

2 网络模型的建立

本文结合漏磁数据的特征、环焊缝在管壁上的空间分布特征,设计了具有多种尺度卷积层的神经网络模型,使得模型具有不同的感受野,从而有效提取环焊缝特征。整体的模型结构如图2所示。模型包括5个卷积层,第1层对输入数据进行3组轴向一维卷积,然后将产生的特征层进行堆叠;第2层进行一次 3×3 卷积;第3层利用 1×1 卷积将特征层数压缩到1,降低参数量;第4层为周向环形卷积,具有周向全局感受野,将特征图压缩为 $1\times W$, W 为轴向截取的漏磁数据采样点数;第5层再做一次 1×9 卷积运算,用于增强环焊缝轴向邻域的特征值。最终,得到了一个参数量仅约为25 K的轻量化网络模型。下面对第1层、第4层、激活函数、样本标签设计、损失函数及预测结果进行详细介绍。




图2 多尺度卷积神经网络模型

Fig. 2 Multi-scale convolution neural network model

2.1 轴向一维卷积

如前所述,由于检测器的振动造成不同传感器偏离值的差异、外界电磁干扰等情况,即使某一位置的管壁无磁导率变化,不同钟点方位的漏磁传感器所返回的数据也可能存在一定的差异,利用广泛使用的 3×3 卷积核进行计算时,这种差异会对结果造成影响。相比之下,同一传感器所返回的数据具有相对的稳定性 and 可比性。于是,在模型的第一层仅使用具有单传感器感受野的轴向一维卷积,即此时只学习同一传感器信号的波动特性,迫使模型规避漏磁数据在周向上的差异。

2.2 周向环形卷积

当检测器遇到环焊缝时,各个钟点方位的漏磁信号均会发生较为明显的响应。为了让模型能够学习到这一特征,模型的第4层使用了具有周向全局感受野和轴向局部感受野的周向环形卷积,卷积核的尺寸为 $H\times 9$, H 为检测器传感器的数量,对应于漏磁数据的行数。周向环形卷积核能够覆盖环焊缝周向一周的漏磁信号,这使得环焊缝空间结构特征得到了充分的利用,能够显著提升模型对环焊缝的特征表示能力。

2.3 激活函数的选择

由于漏磁信号在正负方向均具有明显的波动,因此,

漏磁传感器的返回值是有符号数。于是,模型第1~4层的激活函数使用了双曲正切函数 Tanh,使得负方向的信号波动也能够得到显著响应,进而在模型学习过程中对应的梯度也能够得到更新。模型最后一层的激活函数使用了 Sigmoid 函数,将输出结果向量的各元素压缩到 0~1 之间,用于表示对应位置环焊缝的置信度。

2.4 样本标签设计

标签平滑^[18]可有效地防止模型过度信任训练集的数据,从而防止过拟合现象。标签平滑可产生更紧密的聚类 and 更大的类别间的分离,有助于产生更鲁棒的神经网络,使其在未来的真实数据上进行泛化并表现得更好。

管道环焊缝定位任务最终的预测结果为一个轴向中心坐标,但由于检测器振动、管壁几何形变以及焊缝余高等因素,检测器在行进过程中无法保证漏磁传感器始终在同一个横截面,这导致环焊缝的轴向中心坐标并不是一个绝对清晰的值,其靠近中心的若干个点均可能是环焊缝的中心坐标。因此,在为样本设计标签时,粗暴地指

定某一点即为轴向中心坐标,会使模型过于信任所设定的、并非唯一合理的值,进而降低模型的鲁棒性。于是,借鉴标签平滑的思想,对标签进行了增广设计。首先,为了能够使一条环焊缝对应多个坐标点,将样本标签设计成一个与所截取的数据轴向点数相同的一维向量;其次,将标签向量中靠近环焊缝中心的多个元素设为 1,表示此处为环焊缝所在的区域,其余位置设为 0。这样的标签设计降低了对某一坐标的过度信任,增加了标签的模糊性。相应地,模型的预测结果也不再是一个表示环焊缝轴向坐标的标量值,而是输出一个与所截取的数据轴向点数相同的一维向量,各元素的取值范围为[0,1],表示环焊缝置信度,取值越接近于 1,表示该点对应位置是环焊缝的概率越高,反之越低。于是,即便在一帧漏磁数据中仅包含一条环焊缝,标签也不再是独热码形式的单一标签向量,而是包含多个 1 的多标签向量,模型任务在形式上也演变为一个多标签分类任务。标签设计示意图如图 3 所示。




图3 样本标签设计

Fig. 3 Label design of sample

2.5 损失函数

2.4 节对样本标签进行了增广设计,使得环焊缝定位任务演变为一个多标签分类任务。那么,损失函数应能够反映两个一维标签向量之间的相似程度,于是,本文利用二进交叉熵(binary cross entropy, BCE)作为损失函数,如式(1)所示。

$$Loss(\mathbf{Y}, \mathbf{X}) = -\frac{1}{N} \sum_{i=0}^{N-1} \{ \lambda y_i \log[\sigma(x_i)] + (1 - y_i) \log[1 - \sigma(x_i)] \} \quad (1)$$

其中, N 为标签向量元素的个数; $\mathbf{Y}$ 为样本标签, y_i 为其第 i 个分量; $\mathbf{X}$ 为模型的输出(未经过激活函数), x_i 为其第 i 个分量; $\sigma(\cdot)$ 即为 Sigmoid 激活函数。 λ 用于增加正样本对损失函数的贡献,有助于提升召回率。由于环焊缝漏磁信号动态范围较窄,因此,标签向量中 1 的个数远小于 0 的个数,这种不平衡很容易使模型在学习过程中过于

关注标签中为 0 的元素,而忽略为 1 元素,进而影响模型的召回率,于是,通过 λ 增加正样本对损失函数的贡献。 λ 是一个不小于 1 的超参数,实际使用中设为 5。

2.6 预测结果

模型的输出结果是一个向量,其元素的取值表示环焊缝的置信度,但模型的预测结果中将会有多个值接近于 1,需从中选取合适的位置作为环焊缝坐标的预测值。另外,管道中可能会存在长度较小的管节,即两条环焊缝相距较近,这样,可能会出现同一样本包含两条环焊缝的情况,如果只保留结果向量的全局最大值索引,则会丢失环焊缝。所以,本文利用局部峰值检测方法得到样本中所有环焊缝的索引,即选择在一定范围内为局部极大值且超过置信度阈值的点,作为预测结果。本文设定局部范围为 50 点,即认为 50 点以内不会存在两条环焊缝。

3 实验结果与分析

3.1 建立数据集

本文的训练、验证和测试样本均来自不同管径及不同清晰度的在役管道漏磁内检测数据,共收集了 5 676 份样本,包含环焊缝 4 976 条,并构建了训练集、验证集和测试集。训练集用于模型训练,验证集用于检验模型的收敛情况,进而对模型调参,测试集则用于测试模型的性能。表 1 列出了从不同管径管道内检测数据中搜集的样本情况,以及训练集、验证集、测试集中各种管径管道样本数量及其所包含的环焊缝条数。从表中可以看出,样本覆盖了不同管径管道的漏磁检测数据,其中,Φ457 管道内检测器的漏磁传感器仅有 180 个,而 Φ1219 管道内检测

器的漏磁传感器的则高达 896 个。传感器数量不同,对应漏磁数据样本的行数则不同,即样本的数据维度各异。因此,所建立的数据集具有一定的完备性,这将有助于训练出具有较好泛化能力的网络模型。

此外,数据集中所有包含环焊缝的样本均对应真实管道中不同的环焊缝,即样本具有唯一性,这也有利于网络模型学习到漏磁传感器对不同环焊缝、不同检测器行进速度的响应特性。

从表 1 中还可以看出,样本数量总体上大于环焊缝数量,说明数据集中存在不包含环焊缝的样本,即负样本。本文添加部分负样本的主要原因是,在模型落地应用时,势必会遭遇完全不包含环焊缝的漏磁数据,在模型训练时增加一定数量负样本会减少误检测的概率,提高模型的准确性。

表 1 环焊缝漏磁数据集
Table 1 Girth weld magnetic flux leakage dataset

管径	传感器数量	训练集样本分布		验证集样本分布		测试集样本分布		总计	
		样本数量	环焊缝数量	样本数量	环焊缝数量	样本数量	环焊缝数量	样本数量	环焊缝数量
Φ1219	896	628	524	249	206	652	590	1 529	1 320
Φ813	320	616	571	202	161	224	202	1 042	934
Φ711	280	647	608	218	175	282	234	1 147	1 017
Φ508	336	564	526	178	138	221	205	963	869
Φ457	180	580	488	195	154	220	194	995	836
总计		3 035	2 717	1 042	834	1 599	1 425	5 676	4 976

3.2 数据预处理

1) 数据尺寸变换

不同管径管道所需的漏磁内检测器不同,一般情况下,管径越大,检测器中的传感器数量越多。此外,检测器也分为高清和普通分辨率,高清检测器所部属的传感器数量相对较多,空间分辨率较高。本文样本数据涵盖了多种管道漏磁内检测器,其传感器数量如表 1。在漏磁数据中,传感器数量的差异表现为行数的差异。因此,在送入网络模型前,需对数据进行尺寸变换。管道漏磁检测为轴向逐点采样,可以在轴向截取任意长度,本文将轴向采样点数固定为 416,即一帧漏磁数据样本的列数为 416 列。在周向方向上,对不同管径及分辨率的漏磁数据,进行均匀地上采样或下采样,即等间隔的插入或丢弃若干行数据,使之行数均变换为 416。插值策略选择最近邻插值。这种变换不会显著影响环焊缝空间结构形态以及轴向位置。图 4 以灰度成像的可视化方式展示了 Φ1219 和 Φ457 漏磁数据进行尺寸变换前后的效果图,其中,图 4(a)为 896 行、416 列的 Φ1219 漏磁样本,图 4(b)为经过尺寸变换后的漏磁样本;图 4(d)为

180 行、416 列的 Φ457 漏磁样本,图 4(c)为其经过尺寸变换后的漏磁样本。

2) 数据维度扩展

目前,绝大多数漏磁内检测器均能同时进行漏磁场轴向分量、法向分量及周向分量的测量。管道环焊缝的材料磁导率沿周向方向无明显变化,导致周向分量漏磁信号幅度变化不明显,对环焊缝检测算法贡献较小,本文未使用这一分量。此外,为了提高模型特征提取的效率,一些学者将原始数据的某种变换连同原始数据,同时输入给模型^[19]。文献[20]验证了漏磁场轴向分量和法向分量一阶导数、法向分量和轴向分量一阶导数在动态特性上具有一定的相似性。于是,本文利用这一特性,将轴向分量和法向分量的一阶导数作为扩展维度,与原始的轴向分量和法向分量数据进行堆叠,作为网络模型的输入数据。因此,模型输入数据的维度为 4×416×416。

3) 数据标准化

管道漏磁数据为有符号 16 位整型数,取值范围为 -32 768~32 767,在送入网络前需进行归一化或标准化。由于漏磁数据是有符号数,本文采用标准化作为预处理




图4 漏磁数据尺寸变换效果图

Fig. 4 Size transform of magnetic flux leakage data

手段。为了防止少数奇异点对整帧数据的统计特性造成影响,本文对数据进行逐行标准化处理,这样少量奇异点只对所在的行有影响,大部分有效数据仍然能够保持环焊缝的空间分布特性。数据标准化过程如式(2)所示。

$$\mathbf{X}_{i,:}^c = \frac{\mathbf{X}_{i,:}^c - E(\mathbf{X}_{i,:}^c)}{STD(\mathbf{X}_{i,:}^c)} \quad (2)$$

其中, c 表示漏磁数据第一维的索引值, i 表示漏磁数据第二维的索引值,即行索引, $\mathbf{X}_{i,:}^c$ 为第 c 维、第 i 行的全部漏磁数据, $E(\cdot)$ 为取平均运算, $STD(\cdot)$ 为求标准差运算。

3.3 模型评估

本文使用精度(precision)、召回率(recall)、 $F1$ 值、PR(precision-recall)曲线以及 $F1$ 值曲线评估所提算法的有效性。

如2.4节所述,环焊缝定位任务的预测结果是一个轴向中心坐标,但对于一条环焊缝,其中心坐标并不是绝对清晰的值,在一定范围内都可满足工程上的要求,因此,在对模型评估时也加入了一定的容忍度,对定位正确、定位错误、定位丢失做如下定义:

1) 定位正确:模型预测输出的坐标落入样本标签中标定的环焊缝轴向区间,记为 TP ;

2) 定位错误:模型预测输出的坐标未落入样本标签中标定的环焊缝轴向区间,即模型将管道其它位置误认为是环焊缝,记为 FP ;

3) 定位丢失:模型预测输出的所有坐标均未落入样本标签中标定的某一环焊缝轴向区间,即模型未能检测出该环焊缝,记为 FN ;

于是,对精度 Precision、召回率 Recall 和 $F1$ 值做如下说明:

4) 精度:测试集中被正确定位的环焊缝数量与定位正确和定位错误环焊缝数量之和的比值,如式(3)所示。

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

5) 召回率:测试集中被正确定位的环焊缝数量与所有环焊缝数量之比,如式(4)所示。

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

6) $F1$ 值: $F1$ 值为精度和召回率调和平均值,取值范围为 $0 \sim 1$,如式(5)所示。 $F1$ 值兼顾了精度和召回率的取值情况,能够反映二者的综合性能指标。

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

3.4 模型训练与测试

基于所建立的数据集对模型进行训练和测试。首先,仅利用 $\Phi 1219$ 管道的训练集对模型进行50轮训练,学习率采用cos机制,利用SGD作为优化器。在各管径管道的测试集上分别进行了测试,并在由全部管径管道测试集构成的总的测试集上进行了综合测试,表2列出了置信度阈值为0.9的测试结果。从测试结果可以看出,仅利用从 $\Phi 1219$ 管道漏磁数据中收集的样本对模型实施训练,即可使模型在其它管道测试集上的 $F1$ 值达到较为不错的结果,在全部管道测试集上的最小 $F1$ 值达到了0.88,说明模型有效地学习到了环焊缝的空间结构特性,具备较好的泛化能力。

为了进一步提升模型性能,利用从各种管径管道漏磁数据中收集的全部训练样本对网络模型重新训练,并进行了同样的测试,所得结果记录于表2后半部分。由于训练过程中引入了不同管径的漏磁数据样本,模型能够学习不同管道运行环境中各种因素对漏磁信号动态特性以及噪声特性的影响,模型性能有了进一步提升,在全部管道测试集上的 $F1$ 值超过了0.94。图5和6分别为最终模型在全部测试集上的PR曲线和 $F1$ 值曲线。实际应用时,置信度阈值设置太小则会造成大量定位错误,图5仅画出了置信度阈值在(0.8,1)之间的测试结果。

图7展示了测试集中部分样本的测试结果。图中竖直线即为检测结果对应的环焊缝中心位置,每条竖直线上方显示了检测结果的置信度。通过对错误结果进行分析发现,定位丢失情况主要发生于检测器行进速度较慢的区间,或是环焊缝形状出现了明显扭曲。检测器行进速度较慢时,环焊缝漏磁信号幅值变化平缓,其局部动

表 2 模型测试结果
Table 2 Model test results

训练集	测试集	精度 _{0.9} /%	召回率 _{0.9} /%	F1 值 _{0.9}
Φ1219	Φ1219	94.75	97.80	0.96
	Φ813	87.25	88.12	0.88
	Φ711	86.34	59.40	0.70
	Φ508	90.38	91.71	0.91
	Φ457	89.45	91.75	0.91
	全部	90.39	85.31	0.88
Φ1219+	Φ1219	94.00	94.63	0.94
	Φ813	95.54	91.91	0.94
	Φ711	91.42	94.01	0.93
	Φ508	92.89	97.72	0.95
	Φ457	95.46	97.42	0.96
	全部	93.90	94.79	0.94




图 5 精度与召回率曲线
Fig. 5 Precision-recall curve




图 6 F1 值曲线
Fig. 6 F1 curve

态特性未能突显出来;定位错误情况主要发生在法兰、弯头连接处等管道部件位置,其与环焊缝的空间分布特性较为相似,导致网络将其误识别为环焊缝。

3.5 对比实验

目前,鲜有针对环焊缝定位方法的研究工作,因此无法进行横向对比实验。然而,为了说明所提网络模型各个主要模块的有效性和优势,进行了若干局部对比实验。主要包括轴向一维卷积与二维卷积对比实验、周向环形卷积与二维卷积对比实验、激活函数对比实验以、有无标

签增产两种情况下的对比实验以及损失函数 λ 系数取值对模型性能的影响。

1) 轴向一维卷积对比实验

网络的第 1 层使用了 3 组轴向一维卷积,即 3 组 1×3 卷积,从而降低模型对相邻漏磁传感器信号幅值差异的敏感度。而绝大多数卷积神经网络中常用的卷积核往往是二维 3×3 卷积。本文基于相同的超参数设置,对第 1 层使用 3 组 1×3 卷积和 1 组二维 3×3 卷积两种情况分别训练了 3 次,每次 50 轮。测试结果记录于表 3。

表 3 一维卷积与二维卷积性能比较
Table 3 Comparison of 1D and 2D convolution

卷积结构	参数量 /K	组别	精度 _{0.9} /%	召回率 _{0.9} /%	F1 值 _{0.9} /%
一维卷积 1×3	25.21	1	94.15	94.95	0.95
		2	94.02	94.95	0.94
		3	93.54	94.46	0.94
		平均	93.81	94.97	0.94
二维卷积 3×3	26.36	1	93.61	93.54	0.94
		2	93.90	96.07	0.95
		3	93.84	94.11	0.94
		平均	93.78	94.57	0.94

从表 3 中可以发现,两种模型具相当的数量,模型性能也较为接近。但是,从模型的训练过程发现,在使用 3×3 卷积时,收敛稳定性稍差,如图 8 所示(仅画出前 15 次迭代结果的损失值)。这说明本文所用的网络结构更加贴近目标系统,具有更好的拟合能力。

2) 周向环形卷积对比实验

考虑到环焊缝的空间分布特征,所提模型中使用了周向环形卷积,使得模型具有周向全局感受野和轴向局部感受野,从而能够对环焊缝的空间分布特征进行有效学习。为了考察周向环形卷积对模型性能的贡献,仍使用卷积神经网络中常用的 3×3 卷积将其替换,再进行对比模型性能。具体作法是,将周向环形卷积替换为 3×3 卷积,并增加 1×1 卷积层,将特征层个数压缩到 1 层,最后将该特征层的每一列进行累加,最终仍然得到了一个与轴向采样点数相同的一维向量。对修改后的模型进行了 3 组训练,每次 50 轮。3 组训练结果中,只有 1 组完成了收敛,其余两组均未能收敛,损失函数曲线如图 9 所示。实验结果说明,在未使用周向环形卷积的情况下,网络模型未能有效捕捉环焊缝的特征,模型的收敛出现了较大的随机性。实验结果也同时说明,对于这样一个仅包含 5 个卷积层的网络模型,周向环形卷积对模型性能起到了决定性的作用,对模型特征表示能力具有显著的贡献。




图 7 测试结果示例

Fig. 7 Examples of test results

3) 其他

本文还考察了标签增广、损失函数 λ 系数以及激活函数对模型性能的影响。实验发现,当不实用标签增广时,即在标签向量中仅用一位表示环焊缝的位置,模型未能稳定收敛。当 $\lambda < 5$ 时,模型的召回率偏低;当 λ 在 5 附近时,模型能够同时取得较高的精度和召回率;当 $\lambda > 5$ 时,模型的精度开始缓慢下降。图 10 展示了精度、召回率及 $F1$ 值在 λ 取不同值时的变化趋势(为方便显示, $F1$

值以百分数形式显示)。

目前,卷积神经网络中常用的激活函数是 LeakyReLU 函数或是其变形,本文也进行了对比实验。实验发现,当模型激活函数使用 LeakyReLU 函数时,训练的收敛稳定性较差。在进行的三组训练中,最优模型测试结果与使用 Tanh 时相当;最差模型的收敛过程不稳定,训练误差较大,如图 11 所示,最终测试召回率降到了 80.42%,下降幅度较大。




图 8 一维卷积与二维卷积损失函数曲线比较

Fig. 8 Comparison of loss curve with 1D and 2D convolution




图 9 未使用周向环形卷积的损失函数曲线

Fig. 9 Loss curve with no circular ring convolution in model

通过观察 LeakyReLU 函数曲线即可发现,其负半轴曲线斜率很小,对漏磁数据取负值的部分响应不明显,这是其不适合本文模型的主要原因。此外,为了使得模型能够输出更为明确的结果,在希望环焊缝区间内各点置信度尽量大的同时,也希望其余各点的置信度尽量接近于 0,这就要求最后一层 Sigmoid 函数之前的各层网络输出能够取到负值,而 Tanh 激活函数更加具备这样的特性。虽然 Tanh、Sigmoid 等激活函数存在梯度消失的风险,但本文所提模型是一个仅包含 5 个卷积层的轻量化浅层网络,发生梯度消失的概率较小,相比之下,其对漏磁数据负值的显著响应所带来的益处更加明显。




图 10 损失函数 λ 系数对模型性能的影响

Fig. 10 The effect of λ in loss function on model performance





图 11 损失函数曲线(使用 LeakyReLU)

Fig. 11 Loss curve (LeakyReLU instead)

3.6 模型应用测试

为了进一步测试模型的性能,基于兰—银线河口至甘塘 $\Phi 610$ 管道、约 200 km 的漏磁内检测数据,对模型进行了应用测试。该段管道共包含 17 105 条环焊缝,在置信度阈值设为 0.95 时,算法共召回 17 063 条环焊缝,定位错误结果共 2 718 条(包含 496 条弯头开始或弯头结束),精度达到了 86.25%,召回率到达了 99.75%,F1 值达到了 0.93。这说明模型具有较好的泛化能力,具备一定的工程应用潜力。最后,将检测结果导入管道检测数据分析系统数据库文件中,图 12 展示了若干检测结果。






图 12 模型应用测试效果
Fig. 12 Model application test effectiveness

4 结 论

由于在建模时考虑了漏磁数据的特征以及环焊缝的空间分布特征,模型对环焊缝的特征表示更加高效,其收敛过程更具有导向性。这一方面使得模型的收敛稳定性得到了保证,另一方面也允许模型更加轻量化。通过对比实验,验证了轴向一维卷积和周向环形卷积对模型性能的贡献,以及其它超参数对模型性能的影响。最终利用 1 个仅包含 5 个卷积层、参数量仅为 25 K 的多尺度卷积轻量化神经网络模型,就达到了较为不错的性能,模型在多种管径的检测数据上均呈现出了较好的鲁棒性,在未参与任何训练的 $\Phi 610$ 管道检测数据上也表现出了较好的泛化能力,说明模型已具备一定的工程应用价值,同时也为全面实现漏磁数据分析任务自动化或智能化奠定了一定的基础。然而,模型尚未具备基于上下文内容识别环焊缝与弯头开始位置、弯头结束位置的能力,后续可基于定位结果并设计新的算法,进一步分析目标位置附近的漏磁数据,进而提升结果准确性。

参考文献

[1] 刘桐,刘斌,冯刚,等. 载荷作用下管道漏磁内检测信号量化研究[J]. 仪器仪表学报, 2022, 43(1): 262-273.
LIU T, LIU B, FENG G, et al. Quantization of pipeline magnetic flux leakage detection signal under load[J]. Chinese Journal of Scientific Instrument, 2022, 43(1): 262-273.
[2] SZEGEDY C, IOFFE S, VANHOUCKE V, et al.

Inception-v4, inception-resnet and the impact of residual connections on learning[C]. Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, AAAI Press, 2017: 4278-4284.
[3] 雷春丽,夏奔锋,薛林林,等. 小样本下自校正卷积神经网络的滚动轴承故障识别方法[J]. 仪器仪表学报, 2022, 43(9): 122-130.
FU CH L, XIA B F, XUE L L, et al. Fault identification for rolling bearing by self-calibrated convolutional neural network under small samples conditions [J]. Chinese Journal of Scientific Instrument, 2022, 43 (9): 122-130.
[4] 叶涛,赵宗扬,郑志康. 基于 LAM-Net 的轨道侵入界异物自主检测系统[J]. 仪器仪表学报, 2022, 43(9): 206-218.
YE T, ZHAO Z Y, ZHENG ZH K. Research on the autonomous detection system for railway intrusion obstacles based on LAM-Net [J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 206-218.
[5] 杨珂,方诚,段黎明. 基于深度学习模型融合的铸件缺陷自动检测[J]. 仪器仪表学报, 2021, 42(11): 150-159.
YANG K, FANG CH, DUAN L M. Automatic detection of casting defects based on deep learning model fusion[J]. Chinese Journal of Scientific Instrument, 2021, 42(11): 150-159.
[6] 孙备,左震,吴鹏,等. 面向无人艇环境感知的改进型 SSD 目标检测方法[J]. 仪器仪表学报, 2021, 42(9): 52-61.

- SUN B, ZUO ZH, WU P, et al. Object detection for environment perception of unmanned surface vehicles based on the improved SSD [J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 52-61.
- [7] 熊磊, 王凤随, 钱亚萍. 基于特征融合的自适应多尺度无锚框目标检测算法[J]. 电子测量与仪器学报, 2022, 36(11): 236-244.
- XIONG L, WANG F S, QIAN Y P. Adaptive multi-scale anchor-free target detection algorithm based on feature fusion [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(11): 236-244.
- [8] 刘兰兰, 万旭东, 汪志刚, 等. 基于超分辨率重建与多尺度特征融合的输电线路缺陷检测方法[J]. 电子测量与仪器学报, 2023, 37(1): 130-139.
- LIU L L, WAN X D, WANG ZH G, et al. Transmission line defect detection method based on super-resolution reconstruction and multi-scale feature fusion[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 130-139.
- [9] LIN H, HUANG W M, LUO W Q, et al. DeepFake detection with multi-scale convolution and vision transformer[J]. Digital Signal Processing, 2023, 134: 103895.
- [10] KAR M K, NEOG D R, NATH M K. Retinal vessel segmentation using multi-scale residual convolutional neural network (msr-net) combined with generative adversarial networks[J]. Circuits System Signal Process, 2023, 42: 1206-1235.
- [11] ZOLFAGHARI A, ZOLFAGHARI A, KOLAHAN F. Reliability and sensitivity of magnetic particle nondestructive testing in detecting the surface cracks of welded components [J]. Nondestructive Testing and Evaluation, 2018, 33(3): 290-300.
- [12] LIU B, FENG G, HE L Y, et al. Quantitative study of MMM signal features for internal weld crack detection in long-distance oil and gas pipelines [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70:1-13.
- [13] LANG X L. Recognition method of pipeline weld defects based on auxiliary classifier generative adversarial networks [J]. IEEE Instrumentation & Measurement Magazine, 2022, 25(2): 69-77.
- [14] ZUO F Y, LIU J H, WANG L, et al. Active learning-based complex pipeline weld defect detection with lightweight neural network[C]. IEEE 11th Data Driven Control and Learning Systems Conference (DDCLS), 2022: 712-717.
- [15] GENG L Y, DONG SH H, QIAN W CH, et al. Image classification method based on improved deep convolutional neural networks for the magnetic flux leakage (MFL) signal of girth welds in long-distance pipelines[J]. Sustainability, 2022, 14(19): 1-21.
- [16] YANG L J, WANG ZH J, GAO S W, et al. Magnetic flux leakage image classification method for pipeline weld based on optimized convolution kernel [J]. Neurocomputing, 2019, 365: 229-238.
- [17] SHEN X K, LIU J H, ZHAO H, et al. Research on multi-target recognition algorithm of pipeline magnetic flux leakage signal based on improved cascade RCNN[C]. 2021 3rd International Conference on Industrial Artificial Intelligence (IAI), 2021: 1-6.
- [18] MÜLLER R, KORNBLITH S, HINTON G. When does label smoothing help? [C]. 33rd Conference on Neural Information Processing Systems, 2019, 422: 4694-4703.
- [19] 伍济钢, 文港, 杨康. 改进一维卷积神经网络的航空发动机故障诊断方法[J]. 电子测量与仪器学报, 2023, 37(3): 179-186.
- WU J G, WEN G, YANG K. Improved one-dimensional convolutional neural network for aero-engine fault diagnosis [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 179-186.
- [20] 杨理践, 赵东升, 耿浩, 等. 漏磁信号增强算法研究[J]. 仪器仪表学报, 2022, 43(2): 176-186.
- YANG L J, ZHAO D SH, GENG H, et al. Research on the MFL signal enhancement algorithm [J]. Chinese Journal of Scientific Instrument, 2022, 43 (2): 176-186.

作者简介



赵东升, 2009 年于广西大学获得学士学位, 2011 年于东北大学获得硕士学位, 现为沈阳工业大学在读博士研究生和沈阳工程学院讲师, 主要研究方向为管道检测数据智能分析与处理。

E-mail: 1332906250@qq.com

Zhao Dongsheng received his B. Sc. degree from Guangxi University in 2009, and received his M. Sc. degree from Northeastern University in 2011. He is currently a Ph. D. candidate at Shenyang University of Technology and a lecturer at Shenyang Institute of Engineering. His main research interests include intelligent analysis and processing of pipeline inspection data.



杨理践, 1981 年于沈阳工业大学获得学士学位, 1984 年于哈尔滨工业大学获得硕士学位, 现为沈阳工业大学教授, 主要研究方向为长输油气管道内检测技术及相关理论、无损检测技术。

E-mail: yanglijian888@163.com

Yang Lijian received his B. Sc. degree from Shenyang University of Technology in 1981, and received his M. Sc. degree from Harbin Institute of Technology in 1984. He is currently a

professor at Shenyang University of Technology. His main research interests include in-detection technology of long distance oil and gas pipeline and related theory, nondestructive testing technology.



耿浩(通信作者), 2020 年于沈阳工业大学获得博士学位, 现为沈阳工业大学副教授, 主要研究方向为长输油气管道内检测技术及相关理论、无损检测技术。

E-mail: 1025284323@qq.com

Geng Hao (Corresponding author) received her Ph. D. degree from Shenyang University of Technology in 2020. She is currently an associate professor at Shenyang University of Technology. Her main research interests include in-detection technology of long distance oil and gas pipeline and related theory, and nondestructive testing technology.



田野, 2009 年于华中科技大学获得学士学位, 现为管网集团(新疆)联合管道有限责任公司高级工程师, 主要研究方向为管道完整性研究。

E-mail: tianye04@pipechina.com.cn

Tian Ye received his B. Sc. degree from Huazhong University of Science and Technology in 2009. He is currently a senior engineer at PipeChina (Xinjiang) United Pipeline Co. Ltd. His main research interest is pipeline integrity study.